



Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma

Oğuzhan Sönmez¹, Kenan Zengin²

¹ Tokat GaziOsmanpaşa Üniversitesi, Reşadiye Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Tokat, Türkiye (ORCID: 0000-0003-4456-7036)

² Tokat GaziOsmanpaşa Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0000-0000-0000)

(This publication has been presented orally at HORA congress.)

(First received 1 August 2019 and in final form 25 October 2019)

(DOI: 10.31590/ejosat.638104)

ATIF/REFERENCE: Sönmez, O. & Zengin, K. (2019). Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. *European Journal of Science and Technology*, (Special Issue), 302-308.

Öz

Günümüzde yiyecek – içecek sektörüne olan ilgi sürekli artış göstermektedir. Dolayısıyla pazarda artan rekabet, işletmelerin ayakta kalmaları için teknolojiyle uyumlu çalışmaları zorunlu kılmaktadır. İşletmeler müşterilerin taleplerini tahmin edebilirlerse planlamalarını da ona göre yapacak ve fazla iş gücü ve maliyetten kurtulacaklardır. Doğru olarak yapılan tahminler işletmeye fayda sağlayacak ve gerekli tedbirleri alacaklardır. Çalışmada Tokat bölgesinde faaliyet gösteren bir yiyecek-içecek işletmesinin verileri kullanılmıştır. Bu işletmenin satış tahmini için yapay sinir ağları ve çoklu regresyon modelleri kullanılarak günlük satışını tahmin edip ve iki modelin karşılaştırılması yapılmıştır. İlk çalışma matlab ortamında yapay sinir ağları aracı olan nntool kullanılmıştır. Veriler 2018 yılının ilk 6 ayını içeren 150 satırdan oluşmaktadır ve %70 eğitim %30 ise test için kullanılmıştır. Yapay sinir ağıımız 8 girişli tek gizli katmanlı ve 8 nöronlu tek çıkışlı bir modelden oluşmaktadır. Eğitim fonksiyonu olarak Levenberg-Marquard Algoritması(trainlm) ve aktivasyon fonksiyonu olarak ise tansig fonksiyonu kullanılmıştır. Modelimizde test R oranı %95,77 çıkmıştır. İkinci uygulamamızı anaconda platformunda, spyder ide sini kullanarak python programlama diliyle geliştirdik. Uygulamada yine aynı parametreleri kullanarak çoklu regsesyon modeli uyguladığımız uygulamada ise doğruluk oranımız %91,3 çıkmıştır. Burada kullandığımız parametreleri en küçük kareler yöntemiyle incelediğimizde işletmenin talep tahminini talep tahmininde haftanın günleri ve sıcaklığın yüksek değerde etkilemediğini görmekteyiz. Dolayısıyla çok ekstrem bir gün değilse veya havanın sıcak-soğuk olması işletmenin satışlarına pozitif -negatif yönde bir etki yapmamaktadır. Her iki modelde başarı oranların yüksek olması talep tahmininde yapay sinir ağları ve çoklu regresyon kullanımının pozitif etkisini gözler önüne sermektedir. Yapay sinir ağlarıyla geliştirdiğimiz model çoklu regresyon modeline göre daha başarılı olduğu gözlemlenmiştir. İşletme bulduğumuz sonuçlara göre planlamasını yaparak belirgin parametrelere daha fazla ağırlık verirse cirosunda artış görecektir.

Anahtar Kelimeler: Talep Tahmini, Yapay Sinir Ağları, Çoklu Regresyon, Yiyecek İçecek İşletmeleri

Demand Forecasting in Food and Beverage Enterprises: A Comparison via Artificial Neural Networks and Regression Methods

Abstract

Today, interest in food and beverage sector is constantly increasing. Therefore, increasing competition in the market necessitates technology-compatible works in order to survive. If businesses can anticipate customers' demands, they will make their plans accordingly and avoid excessive labor and cost. Accurate estimates will benefit the enterprise and take the necessary measures. In this study, data of a food and beverage company operating in Tokat region was used. To estimate the sales of this enterprise by using artificial neural networks and multiple regression models, the daily sales are estimated and compared between the two models. In the first study, nntool, an artificial neural network tool, was used in the matlab environment. The data consisted of 150 lines including the first 6 months of 2018 and 70% of the training was used for 30% of the test. Our artificial neural network consists of a single-layered model with 8

inputs and a single-output model with 8 neurons. Levenberg-Marquard Algorithm (trainlm) was used as training function and tansig function was used as activation function. In our model, the test R ratio was 95.77%. We developed our second application on python programming language using spyder ide on anaconda platform. In the application, using multiple regression model using the same parameters, the accuracy rate was 91.3%. When we examine the parameters we use here with the least squares method, we see that the demand forecast of the enterprise does not affect the days of the week and the temperature at high value in demand forecasting. Therefore, if it is not a very extreme day or the weather is hot-cold, it does not have a positive-negative effect on the sales of the enterprise. The high success rates of both models show the positive effect of using artificial neural networks and multiple regression in demand forecasting. The model we developed with artificial neural networks was more successful than the multiple regression model. According to the results we find, if the firm places more weight on certain parameters by planning, it will see an increase in turnover

Keywords: Demand Forecasting, Artificial Neural Networks, Multiple Regression, Food and Beverage Enterprises

1. Giriş

Yiyecek-içecek sektöründeki oyuncuların hızlı değişmesi işletmeleri hızlı ve yeni kararlar almasına yol açabilir. Alınacak kararlar işletmelerin gelecekte ayakta kalmaları ve satışlarını artırmalarına yönelik olmalıdır. Gelecek adına doğru tahminler işletmenin doğru pozisyon almasını sağlayacaktır. Tahmin değerleri ile gerçek değerler arasındaki ilişkiyi doğru okumak işletmeleri zarar etmelerini engelleyecektir.

Talep tahmini için geliştirilen nicel yöntemlere örnek olarak Yapay Sinir Ağları, Genetik Algoritmalar, Destek Vektör Makineleri, Hareketli Ortalamalar Yöntemi, Üstel Düzleştirme Yöntemi, Ekonometrik Modeller, Basit Regresyon Analizi, Çoklu Regresyon Analizi verilebilir (Karaatlı, Helvacıoğlu, Ömürbek ve Tokgöz, 2012). (Karaatlı vd., 2012)

Bu çalışmada işletmelerde günlük yiyecek talebini yapay sinir ağları kullanarak tahmin edebilen ve çoklu regresyon modeli kullanılarak talep tahmini ve karşılaştırma yapılmıştır. Çalışmanın amacı işletmelerin belli parametrelerde ne kadar satış yapabileceklerini tahmin ederek onların yeni aksiyonlar almalarını sağlamaktır. Çalışmayı diğer çalışmalardan ayıran özellik böyle bir çalışma yapılmamış olması. Gerçek verilerden oluşan çalışmada gerçeğe yakın değerler bulması çalışmanın önemini ortaya koymaktadır.

Es ve arkadaşları (2007) Türkiye'nin net enerji talebini, Calp (2018) İşletmeler için personel yemek miktarı tahmini, Efendigil ve arkadaşları (2017) Havacılık sektöründe yolcu talep tahmini, Akdağ (2016) Diyarbakır kent merkezi içme suyu talebini, Eren ve arkadaşları (2017) Perakende giyim sektöründe talep tahmini, Çuhadar ve arkadaşları (2005) Konaklama işletmelerinde doluluk oranı tahmini, Uluçan ve arkadaşları (2018) Konaklama işletmelerinde talep tahmini, Çuhadar ve arkadaşları (2009) Antalya iline yönelik dış turizm talebi tahmini, Başoğlu ve arkadaşları (2016) Kısa dönem elektrik talep tahmini, Yücesan ve arkadaşları (2018) Beyaz eşya sektörü için bir satış tahmini, Hamzaçebi ve arkadaşları (2004) Türkiyede uzun dönemli elektrik enerjisi tüketim tahminini için yapay sinir ağlarını kullanmışlardır. Karaca ve arkadaşları (2016) Elektrik tüketim talebini etkileyen faktörleri, Üstündağ ve arkadaşları (2018) Antalya bölgesinde otel oda fiyatlarının tahmini, Turanlı ve arkadaşları (2003) Turizm sektöründe talep tahmini, Özudoğru ve arkadaşları (2015) sağlık sektöründe talep tahmin için regresyon yöntemini kullanmışlardır.

2. Metaryal ve Yöntemler


Çalışmanın bu kısmında Makine öğrenmesi ve Yapay sinir ağları (YSA) konuları kısaca açıklanmıştır. Verilerin elde edilmesi, gereksiz verilerin temizlenmesi ve verileri eğitim ve test olarak ikiye ayrılarak modelin oluşturulma aşamalarından bahsedilmiştir.

2.1. Makine Öğrenmesi (Machine Learning)

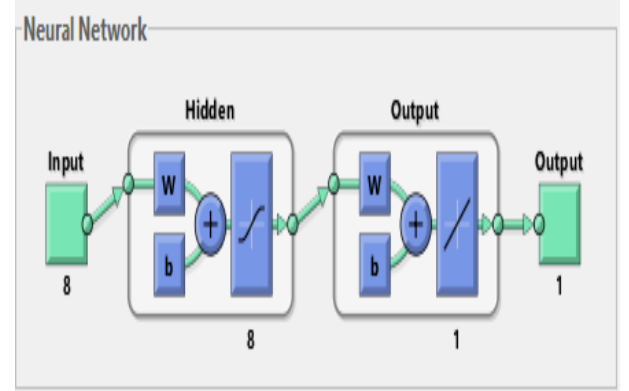
Makine öğrenmesi verilere matematiksel ve istatistiksel işlemler uygulayarak tahminlerde bulunması için algoritmaların tasarım ve süreçlerini konu alan bilim dalıdır. Makine öğrenmesi bir probleme ait verileri problem için modelleyen algoritmalarıdır. Birçok makine öğrenmesi yöntemi geliştirilmiştir. Naive Bayes Sınıflandırıcı, K-en yakın komşu algoritması, destek vektör makinaları, karar ağaçları, lojistik regresyon analizi ve yapay sinir ağları. Makine öğrenmesi algoritmaları sayesinde aralarındaki ilişkilere karar veremediğimiz, göremediğimiz birçok sınıflandırma ve tahmin işlemlerini yapılabilmektedir.

2.2. Yapay Sinir Ağları

YSA, bir sinir hücresinden esinlenerek nöron yapısı göz önünde bulundurularak modellenen ve zamanla kendi kendine öğrenme yeteneği olan bir yöntemdir. YSA insan beyni gibi davranış değişikliği yoluyla yeni bilgiler üretebilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan kendiliğinden gelişen makine öğrenmesi yöntemidir. (Chehreh ve arkadaşları, 2008). Şekil 1'de görüldüğü gibi YSA modeli giriş katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Gizli katman sayısı ve nöron sayıları yapılan çalışmada denemeler sonucu tespit edilebilir. Giriş katmanından herhangi işlem yapılmadan geçen veriler gizli katman ve çıkış katmanında bağlantıların ağırlık değerleri oranında çarpılarak gele veriler toplanır ve transfer fonksiyonuna aktarılır (Yongjae ve arkadaşları, 2005). Çok katmanlı yapay sinir ağları sınıflandırma problemlerini çözmek için kullanılır. Sadece doğrusal problemlerin çözümünde tek nöron yeterli olabilir.



Şekil.1 Girişli tek gizli katmanlı 4 nöronlu 2 çıkışlı YSA



Şekil.2 Verilerimize uyguladığımız YSA modeli

2.3. Verilerin Elde Edilmesi

Veriler 2018 yılında Tokattaki bir işletmenin veritabanından elde edilmiş olup 150 günlük veriler mevcuttur. Veri seti 9 parametreden oluşmaktadır. Çalışmada işletmenin adı “XYZ” olarak geçmektedir

2.4. Matlab Ortamında Modelin Oluşturulması

Modeli oluştururken günlük talebi etkileyeceği düşünülen faktörler dikkate alınmıştır. Bu faktörler; Döner, Izgaralar, Kebaplar, Çorba, İçecek, Gerçekleşen hava sıcaklığı, müşterilerin satınalma gücünü etkileyen gerçekleşmiş enflasyon verisi ve haftanın günleri (Pazartesi, Salı, Çarşamba, Perşembe, Cuma, Cumartesi, Pazar) olarak belirlenmiştir.

Çizelge 1. Verilerin Bir Kısmı

GUNLER	ENFLASYON	HAVA	DONER	IZGARALAR	KEBAPLAR	CORBA	ICECEK	SATIS
Pazartesi	10.35	8	39	19	17	25	75	1878
Salı	10.35	9	54	18	9	24	56	1886
Carsamba	10.35	11	47	46	15	28	79	2686
Persembe	10.35	11	44	29	20	16	52	1978
Cuma	10.35	12	95	47	43	19	175	4090
Cumartesi	10.35	11	62	34	18	14	119	2670
Pazar	10.35	9	58	17	12	13	56	1816
Pazartesi	10.35	7	37	21	13	15	46	1586
Salı	10.35	7	64	30	11	15	73	2265
Carsamba	10.35	8	68	27	22	24	91	2565
Persembe	10.35	9	41	27	18	15	56	1922
Cuma	10.35	7	32	37	20	15	64	1988
Cumartesi	10.35	7	69	41	20	24	102	2871
Pazar	10.35	5	107	32	23	58	126	4235
Pazartesi	10.35	4	59	38	30	16	72	2921
Salı	10.35	8	84	31	14	26	92	2895
Carsamba	10.35	8	101	38	35	33	130	4191
Persembe	10.35	9	58	23	12	16	60	2134
Cuma	10.35	5	88	37	19	15	92	3038
Cumartesi	10.35	9	60	23	24	15	104	2599
Pazar	10.35	13	76	32	30	15	114	3121

2.4.1 Eğitim ve Test Süreci

Matlab programında 150 adet gerçek veri içerisinde %70 eğitim %30 kısmı test için ayrılmıştır. Eğitim ve test süreçlerine başlanmıştır. Modeli 20 kez uygulayıp ortalamasını alarak rastgele düşük veya yüksek oranlar yüzünden yanılma payını minimize ettik.

2.4.1.1 Levenberg-Marquard Algoritması


LM algoritması Dik iniş (Steepest descent) ve Newton algoritmalarından türetilmiştir. Ağırlık vektörü w , birim matris I , kombinasyon katsayısı μ . Jacobian matrisini J ($P \times M$) $\times N$, hata vektörünü e ($P \times M$) $\times 1$ göstermektedir. Eğitim örnek sayısını P , çıkış sayısını M ve ağırlık sayısını N göstermektedir. μ ayarlanabilir bir parametredir.

$$\Delta w = (J^T J + \mu I)^{-1} J^T e$$

2.4.1.2 Tansig Fonksiyonu

Aktivasyon fonksiyonu için giriş-çıkış ifadesi (1) de fonksiyonun değişimi şekil 3'de verilmiştir. Fonksiyonun değişim aralığı $[-1, 1]$ aralığındadır ve toplam nöron girişe bağlı olarak fonksiyon lineer olmayan bir değişim gösterir.

$$a = \frac{2}{1 + e^{(-2n)}} - 1 \quad (1)$$

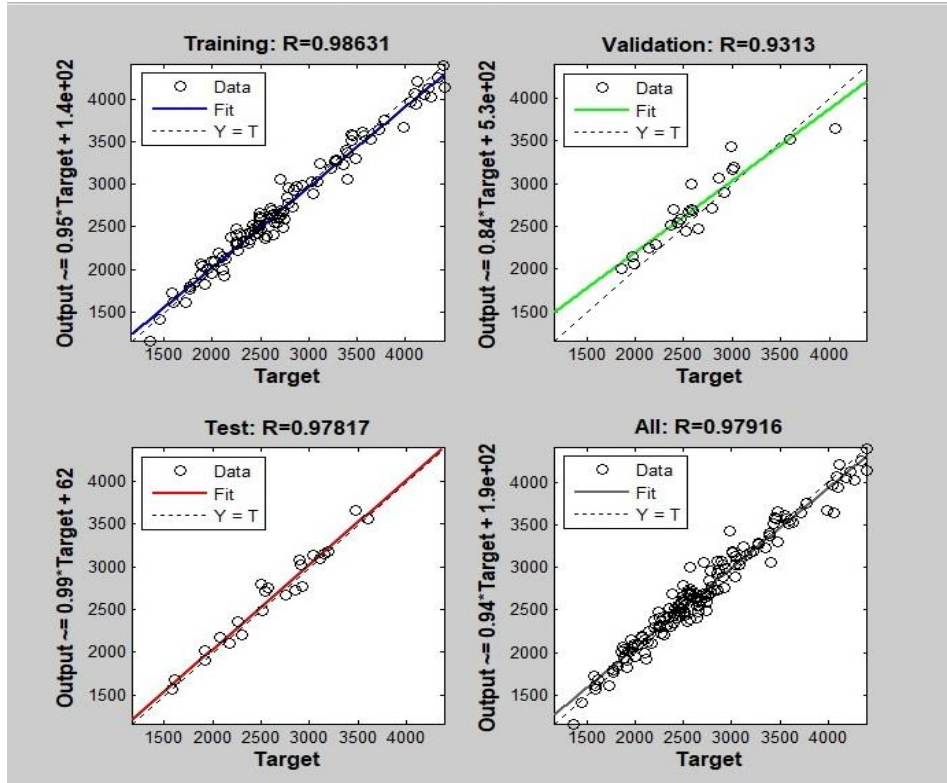


Şekil.3 Tangent-Sigmoid fonksiyonu giriş-çıkış eğrisi

Çizelge 2. Performans Sonuçları

No	Eğitim Fonksiyonu	Aktivasyon Fonksiyonu	Gizli Katman	Gizli katdaki Nöron Sayısı	Eğitim R Oranı	Doğruluk R Oranı	Test R Oranı
1	trainlm	tansig	1	8	0.98456	0.98049	0.96041
2	trainlm	tansig	1	8	0.98607	0.97487	0.97027
3	trainlm	tansig	1	8	0.98941	0.9642	0.96197
4	trainlm	tansig	1	8	0.99022	0.96924	0.97543
5	trainlm	tansig	1	8	0.9623	0.95429	0.96575
6	trainlm	tansig	1	8	0.99059	0.9555	0.95383
7	trainlm	tansig	1	8	0.9816	0.98266	0.971
8	trainlm	tansig	1	8	0.99247	0.92508	0.97343
9	trainlm	tansig	1	8	0.98988	0.96762	0.96845
10	trainlm	tansig	1	8	0.98831	0.92483	0.93815
11	trainlm	tansig	1	8	0.99272	0.975	0.965
12	trainlm	tansig	1	8	0.98913	0.96833	0.98589
13	trainlm	tansig	1	8	0.99244	0.97815	0.96123
14	trainlm	tansig	1	8	0.98009	0.94742	0.97358
15	trainlm	tansig	1	8	0.98839	0.974409	0.96105
16	trainlm	tansig	1	8	0.98995	0.95364	0.95016
17	trainlm	tansig	1	8	0.98294	0.95817	0.96826
18	trainlm	tansig	1	8	0.97669	0.98153	0.96781
19	trainlm	tansig	1	8	0.96956	0.96775	0.98283
20	trainlm	tansig	1	8	0.99192	0.94121	0.97122
Ortalama					0.985462	0.962219	0.966286

Çizelge 2 incelendiğinde uygulanan fonksiyonlar, katman sayısı, nöron sayıları ve bunlara karşılık eğitim, test ve doğruluk oranları görülmektedir. Veriler eğitildikten sonra denemeler sonucunda modelin eğitim-test değerlerine bir örnek Şekil 4'de verilmiştir. Eğitim R oranı ile test doğruluk oranı arasındaki fark çok yüksek olmadığı için sistemin herhangi bir ezberleme yapmadığını görmekteyiz. Test R oranı %96,628 olarak karşımıza çıkmaktadır bu sonuç modelin verimli çalıştığını gösteriyor diyebiliriz.



Şekil.4 Modelin Eğitim ve Test R değerleri

2.5. Python Ortamında Modelin Oluşturulması

Çizelge 1’de bulunan veriler python programına data dosyası import edildi.

2.5.1. Verilerin Eğitim ve Test Süreci

Python programlama dilinde verilerin %70 eğitim %30 test verisi olarak sisteme dahil edilmiştir.

2.5.2 Pandas Kütüphanesi

Pandas python programlama dili için yüksek performanslı, kullanımı kolay veri yapıları ve veri analiz araçları sağlayan açık kaynaklı bir BSD lisanslı kütüphanedir. Csv ve text dosyalarını açmaya ve içerisinde bulunan verileri okuyarak istenen sonuca kolayca ulaşmak için kullanılmaktadır.

2.5.3. Numpy Kütüphanesi

NumPy (Numerical Python) bilimsel hesaplamaları hızlı bir şekilde yapmamızı sağlayan bir matematik kütüphanesidir. Numpy’ın temelini numpy dizileri oluşturur. Numpy dizileri python listelerine benzer fakat hız ve işlevsellik açısından python listelerinden daha kullanışlıdır. Ayrıca python listelerinden farklı olarak Numpy dizileri homojen yapıda olmalıdır yani dizi içindeki tüm elemanlar aynı veri tipinden olmalıdır. (Durna, 2019).

2.5.4 Scikit-learn Kütüphanesi

Scikit-learn yapay öğrenme alanında en yaygın olarak kullanılan kütüphanelerden biri. Doğrusal regresyon, lojistik regresyon, karar ağaçları, rastgele orman gibi birçok temel yöntemi içeren bu kütüphanedir. (Yüceoğlu, 2019)


2.5.6 Çoklu Regresyon

Çoklu regresyon bir adet bağımlı değişken ve birden fazla bağımsız değişkenin bir arada bulunduğu modeldir. Gerçek dünyada, tüm verileri anlamlı bir şekilde tanımlayan doğrusal fonksiyonlar bulunmayabilir, bazı durumlarda veri kümemizi eğri bir fonksiyon ile tanımlayabiliriz (Ulgen, 2019)

$$Y = b_1 + b_2 X_2 + b_3 X_3 + \dots + b_k X_k + u$$

2.5.7 En Küçük Kareler Yöntemi

Regresyon çözümlemesinde amaç gerçek Y'ye (sonuca) olabildiğince yakın değerler veren katsayı tahminleri bulmaktır. Şekil 5'de modelin grafiği bulunmaktadır.



Şekil.5 En Küçük Kareler Yöntemi

IPython console

```

[ 0.  0.  0.  0.  0.  1.  0. 10.35 11. 47. 46. 15.
 28. 79. ]

OLS Regression Results
=====
Dep. Variable:          y    R-squared:          0.947
Model:                OLS    Adj. R-squared:     0.944
Method:               Least Squares    F-statistic:       423.0
Date:                 Fri, 19 Jul 2019    Prob (F-statistic): 2.32e-88
Time:                 15:44:51    Log-Likelihood:    -968.80
No. Observations:    150    AIC:               1952.
Df Residuals:        143    BIC:               1973.
Df Model:             6
Covariance Type:     nonrobust
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	-327.4630	116.485	-2.811	0.006	-557.717	-97.209
x1	38.0390	8.754	4.346	0.000	20.736	55.342
x2	14.3635	1.036	13.860	0.000	12.315	16.412
x3	19.5925	1.840	10.650	0.000	15.956	23.229
x4	19.4330	2.149	9.041	0.000	15.184	23.682
x5	10.1351	1.628	6.227	0.000	6.918	13.352
x6	5.3412	0.781	6.843	0.000	3.798	6.884

```

=====
Omnibus:                44.818    Durbin-Watson:         1.478
Prob(Omnibus):          0.000    Jarque-Bera (JB):      112.586
Skew:                   1.218    Prob(JB):              3.57e-25
Kurtosis:               6.475    Cond. No.              1.10e+03
=====

```

Şekil.6 Sonucu Etkileyen faktörler

	0
0	2265
1	2140
2	1860
3	4344
4	2706
5	4399
6	4063
7	2506
8	2649
9	2486
10	3783
11	2177
12	2263

	0
0	2317.29
1	2214.83
2	1887.46
3	4335.89
4	2750.34
5	4526.27
6	3930.94
7	2384.92
8	2461.3
9	2593.55
10	3894.25
11	2249.13
12	2153.04

Şekil.7 Test verisi ile Sistemin tahminlerinin karşılaştırılması

Şekil 6'de sonucumuzu en çok etkileyen faktörlerin tespitini en küçük kareler yöntemiyle tespit ettik ve Şekil 6'da test verilerimiz ile modelin tahmin sonuçlarının karşılaştırması bulunmaktadır. Şekil 7'da anlaşılacağı gibi test verileri ile tahmin verileri arasındaki uyum gayet iyi görünmektedir. Doğruluk oranında %91,3 olarak görülmektedir.

3. Sonuç ve Tartışma

Çalışmada 2018 yılı XYZ işletmesinin günlük satış cirosu, ürün çeşitleri, ekonomik satın alma gücü, gerçekleşen hava sıcaklığı ve haftanın günlerini sisteme girdi olarak tanıttık. Bu değerlerin %70 eğitim için %30 test için kullandık. Matlab ortamında bu verilerden yapay sinir ağları yöntemiyle tahminler yaptık. Yapılan bu tahminlerde ortalama test başarı oranı ortalama %96,662 değerine ulaşmıştır. Python programlama dilinde yaptığımız çoklu regresyon uygulamasıyla ise doğruluk oranı %91,3 olarak gerçekleşmiştir. Regresyon yöntemiyle sonuç değişkenimize en az etki eden faktörleri belirledik bunlar haftanın günleri ve hava durumu olarak karşımıza çıktı. YSA'nın başarısı test değerlerinden anlaşılmaktadır.

Çalışmada YSA daha başarılı yöntem olarak göze çarpmaktadır. Kullandığımız veri setindeki veri çeşitliliğinin fazla olması durumunda parametreler arasındaki ilişkiyi inceleme fırsatımızda olacaktır. Giriş parametlerini daha çok çeşitlendirebilirsek ve verisetinde artırabilirsek sistem başarısı daha da yukarı çıkacaktır. Maksimum talebin hangi şartlarda oluşacağını da karar ağacı algoritmasını kullanarak da bulabiliriz.

Kaynaklar

- Akdag, R. (2016). Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-Jenkins Yöntemleriyle Kentsel İcmesuyu Talebi Tahmini ve Karşılaştırmalı Analizi. *Business and Economics Research Journal*, 7(1), 123-138
- Başoğlu, B., ve Bulut, M. (2017). Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 575-583.
- Calp, M. H. (2019). İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi. *Politeknik dergisi*. 22(3), 675-686
- Chehreh, C S, James, C H, Jorjani, E, Mesroghli, S ve Bagherieh, A H, (2008). Prediction of coal grindability based on petrography, proximate and ultimate analysis using multiple regression and artificial neural network models. *Fuel Processing Technology*, 89,13-20.
- Çuhadar, M., ve Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme. *Anatolia: Turizm Araştırmaları Dergisi*, 16(1), 24-30.
- Çuhadar, M., Güngör, İ., ve Göksu, A. (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114.
- Durna, M. B., “Veri Bilimi İçin Temel Python Kütüphaneleri-1: Numpy” (Erişim tarihi 2019.05.14) <https://medium.com>
- Efendigil, T., ve Eminler, Ö. E. (2017). Havacılık Sektöründe Talep Tahmininin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli. *Journal of Yasar University*, 12, 14-30
- Eren, U., ve Satoğlu, Ş. I. Perakende Giyim Sektöründe Yapay Sinir Ağları ile Talep Tahmini.
- Es, H. A., Kalender, F. Y., ve Hamzaçebi, C. (2014). Yapay sinir ağları ile Türkiye net enerji talep tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 29(3), 227-233
- Hamzaçebi, C., ve Kutay, F. (2004). Yapay sinir ağları ile türkiye elektrik enerjisi tüketiminin 2010 yılına kadar Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3).
- Karaatlı, M., Helvacioğlu, Ö. C., Ömürbek, N., ve Tokgöz, G. (2012). Yapay sinir ağları yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karaca, C., ve Karacan, H. (2016). Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 4(3), 182-195.
- Özüdoğru, A. G., ve Görener, A. (2015). Sağlık sektöründe talep tahmini üzerine bir uygulama. *İstanbul Ticaret Üniversitesi Sosyal Bilimleri Dergisi* 27(Bahar), 37-53
- Turanlı, M. (2003). Turizm sektöründe talep tahmin modellemesi. *İstanbul Ticaret Üniversitesi Dergisi*, 3(Haziran), 1-13
- Ulgen, K. E. “Makine Öğrenimi Bölüm-6 (Regresyon)” (Erişim 2019.05.14) <https://medium.com/>
- Ulucan, Ö. G. E., ve Kızılırmak, İ. (2018). Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları İle İlgili Bir Araştırma. *Seyahat ve Otel İşletmeciliği Dergisi*, 15(1), 89-101.
- Üstündağ, H., ve Sayım, I. Ş. I. (2018). Antalya Bölgesinde Otel Oda Fiyatlarının Tahmini. *Journal of Travel and Hospitality Management*, 15(3), 703-716.
- Yongjae, K, Sehun, R, (2005). Arc sensor model using multiple-regression analysis and a neural network. *ProQ. Sci. J.* ,219, 431-447.
- Yucesan, M., Gul, M., ve Celik, E. (2018). A multi-method patient arrival forecasting outline for hospital emergency departments. *International Journal of Healthcare Management*, 1-13.
- Yüceoğlu, Birol “Scikit-Learn ile Veri Analitiğine Giriş” (Erişim tarihi 2019.05.14) <http://www.veridefteri.com/>